

**UNIVERSIDADE FEDERAL DE SÃO PAULO
ESCOLA PAULISTA DE POLÍTICA, ECONOMIA E NEGÓCIOS**

CAIO LEONARDO PILÃO DE ALMEIDA

**PREVISÃO DA PRODUÇÃO INDUSTRIAL COM VAR BAYESIANO COM
SHRINKAGE PRIOR**

**OSASCO
2019**

CAIO LEONARDO PILÃO DE ALMEIDA

**PREVISÃO DA PRODUÇÃO INDUSTRIAL COM VAR BAYESIANO COM
SHRINKAGE PRIOR**

Monografia apresentada à Escola Paulista de Política, Economia e Negócios da Universidade Federal de São Paulo como requisito parcial para obtenção de grau de Bacharel em Ciências Econômicas.

Orientador: Prof. Dr. Diogo de Prince Mendonça

OSASCO

2019

Catálogo na Publicação
Serviço de Biblioteca e Documentação da Unifesp/Campus Osasco
Escola Paulista de Política, Economia e Negócios – EPPEN
Dados fornecidos pelo (a) autor (a)

Almeida, Caio Leonardo Pilão de

Título: Previsão da Produção Industrial com VAR Bayesiano com Shrinkage Prior – 2019.

Título em inglês: Industrial Production Forecast with Bayesian VAR with Shrinkage Prior

Monografia (Graduação em Ciências Econômicas) – Universidade Federal de São Paulo, Escola Paulista de Política, Economia e Negócios, Osasco, 2019.

Orientador: Prof. Dr. Diogo de Prince Mendonça

1. Previsão. 2. Indústria. 3.BVAR. 4. Desagregação.

RESUMO

O entendimento do comportamento de agregados econômicos é necessário para tomada de decisões na economia. Um dos principais indicadores que revelam a situação econômica de um país é o Produto Interno Bruto (PIB). Por ser um indicador com periodicidade de divulgação trimestral, com defasagem na divulgação de cerca de dois meses e sem informação dentro do trimestre, não foi utilizado neste trabalho. Em alternativa, foi utilizada neste trabalho uma *proxy*, sendo ela o índice de produção industrial, o qual tem menor defasagem entre realização e a divulgação dos dados. O objetivo do trabalho é analisar se o uso das informações setoriais aumenta a acurácia da previsão da produção industrial brasileira de um a doze meses à frente no período através de um Vetor Autorregressivo (VAR). Dado o grande número de variáveis a serem trabalhadas será utilizada a metodologia Bayesiana BVAR com *shrinkage prior* de Banbura *et al* (2010) para permitir estimar um modelo com alta dimensionalidade. Os dados utilizados são o índice agregado e desagregado por setores de forma a concluir se a desagregação traz melhorias na acurácia do modelo. O período analisado é de fevereiro/2002 a maio/2019.

Palavras-chave: Previsão, VAR Bayesiano, Desagregação.

Abstract

The understanding of macroeconomics aggregates behavior is necessary for decisions-making in economy. One of the main indicators that reveals the economic situation of a country is the Gross Domestic Product (GDP). It is not used here due the fact of being a quarterly indicator with lag on the disclosure around two months and with no information in the quarter. As an alternative I use a proxy of the GDP: the Industrial Production indicator. It has less lags on your disclosure in a comparison with the GDP. My objective is to analyses if the use of sectorial information increases the accuracy of the Brazilian Industrial Production forecast. It is used a window of twelve months ahead through an Autoregressive Vector (VAR). Due the high number of variables to work I use a Bayesian methodology called shrinkage prior in Banbura et al (2010). The use of shrinkage prior method allows estimating a high dimensional model. The data I use are the aggregated indicator e disaggregated by sectors. In this way I try to conclude if disaggregation brings accuracy to the model. I analyze the period between February/2002 to May/2019.

Key-words: Forecast, Bayesian VAR, Disaggregation.

SUMÁRIO

RESUMO

ABSTRACT

1	INTRODUÇÃO	6
2	REVISÃO DA LITERATURA	8
3	METODOLOGIAERRO! INDICADOR NÃO DEFINIDO.	12
4	RESULTADOS.....	16
5	CONCLUSÃO	20
6	REFERÊNCIAS.....	21
7	APÊNDICE.....	24

1 INTRODUÇÃO

Agentes econômicos decidem tomar decisões nas esferas público e privada sejam em investimentos ou consumo com base em suas expectativas em relação ao futuro e a presente situação da economia de um país. A previsão de grandes agregados macroeconômicos auxilia na tomada de decisão e para isso é importante a geração de previsões acuradas, testando diferentes tipos de modelos econométricos. Previsões não acuradas podem reverberar em altas perdas financeiras para os grandes players econômicos que tomam decisões de investimento com base, por exemplo, na expectativa de demanda.

A principal variável *proxy* que serve como indicador da situação econômica de um país é o Produto Interno Bruto (PIB), no entanto a sua divulgação aos agentes tem uma periodicidade trimestral, o que acarreta em um menor número de dados históricos para realização da previsão. Além disso, o PIB apresenta uma defasagem de cerca de dois meses, o que dificulta analisar a situação econômica de um país em tempo real para tomar decisões. Assim, uma alternativa é utilizar a produção industrial que apresenta frequência mensal e uma defasagem de cerca de um mês. O ganho ao usar a produção industrial é ter uma maior quantidade de dados e uma menor defasagem para tomar decisão com informações em tempo real.

Este trabalho tem como objetivo analisar a acurácia da previsão de 01 a 12 meses da variação do índice de produção industrial brasileiro a partir de suas defasagens e das defasagens das desagregações da produção industrial. Para isso, utiliza-se um Vetor Autorregressivo Bayesiano (BVAR) com *shrinkage prior* baseado em Banbura *et al* (2010) para analisar se as desagregações da produção industrial auxiliam na previsão da indústria geral, com dados históricos entre fevereiro/2002 a maio/2019. O objetivo da utilização do BVAR com *shrinkage prior* é reduzir o alto número de parâmetros a serem estimados.

A contribuição do trabalho é trazer uma abordagem ainda não realizada pela literatura nacional da performance do modelo BVAR com *shrinkage prior* para a previsão da produção da indústria geral.

Os resultados apontam uma melhor performance para um modelo *naive* autorregressivo de ordem 1 (AR (1)), utilizado como *benchmark*, em relação ao BVAR com *shrinkage prior*, na medida que o erro quadrático médio, na média, é menor para todos horizontes de previsão de 01 a 12 meses do modelo *naive*. A partir do teste de

Diebold e Mariano (1995), considerando-se um nível de significância de 10%, obtém-se resultado de melhor acurácia estatística nas previsões para o AR (1) de 01 a 03 períodos a frente. Para 4 períodos a frente, ambos os modelos apresentam previsibilidades iguais estatisticamente. Banbura *et al* (2010) e Garcia *et al* (2017) ao lidar com o problema de alta dimensionalidade chegam a resultados positivos quanto ao uso do BVAR com *shrinkage prior* em seus trabalhos. Ambos conseguem boas performance, numa comparação de erros de previsão, ao utilizar informações desagregadas.

Este trabalho está dividido em 5 seções, além da introdução. A próxima seção apresenta uma revisão da literatura de trabalhos que estimaram modelos com dados desregrados em comparação àqueles que utilizaram agregados. A terceira seção traz uma explicação da metodologia utilizada, um BVAR com *shrinkage prior*, a partir do qual pretende-se chegar a uma previsão da indústria geral utilizando dados setoriais. Por fim, aborda-se as conclusões do trabalho quanto a acurácia da previsão da indústria geral no modelo aqui proposto.

2 REVISÃO DA LITERATURA

Um ponto de partida importante para qualquer tomada de decisão sobre as metodologias de previsão a serem utilizadas estão relacionadas ao tipo de dados que serão utilizados para realizar a previsão, podendo ser eles agregados ou desagregados. A grande discussão está no fato de qual traz maior acurácia a previsão, dadas circunstâncias de horizonte de tempo a ser previsto, característica dos dados, etc.

Um dos percussores neste debate é Lütkepohl (1984). O autor analisa diferentes tipos de dados com um modelo Autorregressivo de Médias Móveis (ARMA) a partir de componentes desagregados, para depois agregar as previsões e avaliar se traz maior acurácia a previsão ao invés de utilizar a série agregada diretamente. Como conclusão, Lütkepohl (1984) obtém que a utilização de séries desagregadas trará melhorias na medida que o processo gerador dos dados seja conhecido. Caso não seja conhecido, pode ser preferível a previsão diretamente a partir de dados agregados.

Seguindo nesta linha Stock e Watson (1998) realizam uma previsão da inflação nos Estados Unidos com período a frente de 12 meses utilizando uma curva de Philips aumentada, não só com desemprego e sim com mais 167 variáveis propondo um nível de desagregação. Os autores utilizam apenas modelos lineares e chegam a conclusão de uma melhor acurácia para previsão da inflação americana no curtíssimo prazo. Em relação aos usuais *benchmarks* de modelos univariados, como AR e Passeio aleatório, a curva de Phillips convencional (baseada apenas na taxa de desemprego) traz maior acurácia ao modelo. O ganho, na avaliação dos autores, em relação a curva convencional estará na adição de uma composição de atividades agregadas com 168 índices de medição no lugar da taxa de desemprego.

Espasa, Senra e Albacete (2002) realizam um exercício para a inflação na zona do euro, o *Harmonized Indices of Consumer Prices* (HICP). Os autores partem do pressuposto que previsões mais acuradas para o índice resultam da desagregação dos índices de inflação por país e por grandes grupos de mercado. A desagregação é tida como importante na medida que a falta de cointegração entre os elementos do vetor de índices prejudica a agregação dos dados.

Duarte e Rua (2005) trazem um novo fator à discussão da desagregação ao realizar a previsão de inflação no curto prazo para Portugal com dados desagregados.

São testados modelos com dados agregados e também modelo com diferentes níveis de desagregação, com cinco subcomponentes e 59 subcomponentes. São considerados modelos univariados (SARIMA) e multivariados (SARIMAX). A conclusão é que agregar previsões parece melhor do que prever de forma diretamente agregada até 5 períodos a frente, chegando a uma relação inversa entre nível de desagregação e período de previsão, ou seja, o nível de desagregação é melhor para o curtíssimo prazo. Chega-se também a conclusão da preferência pelo modelo multivariado ao univariado no curto prazo.

Marcellino, Stock e Watson (2003) também realizam previsões para inflação na zona do euro com dados desagregados, corroborando com as ideias apresentadas em Espasa, Senra e Albacete (2002), no qual abordam problemas relacionados a desagregação como a má especificação do modelo. Seguem critérios de comparação dos modelos de acordo com a Raiz Quadrada Média do Erro de Previsão e o teste de Diebold e Mariano (1995). Os autores concluem que a desagregação é melhor para previsões até 5 períodos a frente, depois deste período o ganho só é maior com o aumento do nível de desagregação.

Hendry e Hurbich (2011) trazem uma alternativa diferente ao uso da desagregação ao propor realizar previsões agregadas adicionando variáveis desagregadas ao invés de combinar previsões desagregadas com um modelo agregado. Utilizam da simulação de Monte Carlo para testar a hipótese de que incluir informação desagregada no modelo agregado melhora a acurácia da previsão. Os autores destacam questões de má especificação do modelo, incerteza na estimação e quebras estruturais. Para contornar estes problemas podem ser utilizadas métodos de *Bayesian shrinkage* ou Modelo de fatores para reduzir a dimensionalidade do problema e a incerteza sobre as estimações, segundo Hendry e Hurbich (2011). Os autores concluem que incluir variáveis desagregadas no modelo agregado melhoraria a previsão caso as estruturas estocásticas fossem diferentes. Os autores recomendam utilizar seleção de variáveis e escolher desagregados que adicionem ao modelo agregado ou métodos para combinar a informação desagregada.

Weber e Zika (2013) examinam se o uso de informação desagregada aumenta a acurácia da previsão do modelo agregado, a partir de dados do mercado de trabalho na Alemanha. Os autores utilizam um VAR com informações desagregadas ao nível de indústria. Os autores concluem que a desagregação melhora a previsão do emprego. Como teste para comparação utilizam o teste de Clark e West (2007).

Segundo a literatura os benefícios da utilização de informações desagregadas dependem das propriedades das variáveis a serem previstas e seus subcomponentes. Além disto, Weber e Zika (2013) destacam que a desagregação é especialmente importante em períodos de crescimento e recessão nos números de emprego, sendo que em momentos de estagnação tais desagregações não são necessárias, sendo um bom modelo um simples modelo AR.

Seguindo uma linha parecida aos autores mencionados, no Brasil, Carlos e Marçal (2013) testam a eficiência de previsões com metodologias diferentes para o índice de Preços ao Consumidor (IPCA,) comparando modelos com o uso de dados agregados e desagregados e um horizonte de previsão de 12 meses à frente. Os modelos desagregados são estimados por meio de um SARIMA e terão diferentes níveis de desagregação. Para os agregados, a estimação baseia-se nas técnicas de modelos estruturais como o espaço-estado, SARIMA e *Markov-Switching* para modelagem não linear. A comparação da acurácia da previsão será realizada por meio do *Model Confidence Set* e o teste de Diebold e Mariano (1995). As evidências obtidas são de ganho de acurácia em modelos usando dados desagregados, procurando identificar a melhor técnica de estimação do IPCA entre modelos univariados de séries temporais. Os autores concluem também que as previsões com desagregações são melhores para curto espaços de previsão. O modelo não linear de *Markov-Switching* (o qual incorpora quebras estruturais como ciclos econômicos, medidas de revisão dos indicadores que são mais comuns em países em desenvolvimento) mostra-se o pior.

Prince, Marçal e Pereira (2019) investigam se o uso de dados desagregados traz maior acurácia à previsão de 12 meses à frente da taxa de crescimento do índice de produção industrial brasileiro. Os autores utilizam uma amostra de dados de Janeiro/2002 a Agosto/2017. Prince, Marçal e Pereira (2019), utilizam algumas técnicas econométricas, sendo as principais: *weighted lag adaptative least absolute shrinkage and selection operator* (WLadaLASSO); alisamento exponencial (para escolha do modelo) e o algoritmo Autometrics para modelar dados agregados e desagregados. Para realização da previsão, os autores realizam a previsão dos subcomponentes dos dados agregados, atribuindo pesos a cada um. Prince, Marçal e Pereira (2019), chegam a conclusão de melhor acurácia utilizando dados agregados para 01 a 07 meses de previsão como o modelo de alisamento exponencial. O algoritmo Autometrics traz melhor acurácia para 8 a 12 meses sem conclusão entre

a utilização de dados agregados e desagregados. Como medidas de acurácia e comparação de modelos os autores utilizam o erro quadrático médio, o teste de Diebold e Mariano (1995) e o *Model Confidence Set* baseado em Hansen *et al* (2011). Fica claro uma tendência na literatura a conclusões de resultados semelhantes quanto à relação inversa entre nível de desagregação e horizonte de previsão, havendo algumas variações entre autores quanto a tipos de modelagens.

3 METODOLOGIA

A metodologia BVAR com *shrinkage prior* é utilizada para trabalhar um VAR com muitas variáveis, a qual será utilizada neste trabalho como modelagem para previsão da produção industrial brasileira. A metodologia é descrita por Banbura *et al* (2010). Adicionar variáveis em um VAR eleva a perda de graus de liberdade. No caso de um VAR com um elevado número de variáveis sendo modeladas, a alta dimensionalidade dificulta sua estimação pela perda de graus de liberdade. Este problema pode ser levado ao caso limite, em que há mais parâmetros a serem estimados do que observações disponíveis.

O uso de uma *shrinkage prior* traz uma alternativa para reduzir a dimensionalidade do problema.

3.1 DADOS

Para realização da previsão de 1 a 12 meses à frente da variação do índice de produção industrial brasileiro foram utilizados dados da Pesquisa Industrial Mensal Produção Física – Brasil (PIM-PF) provenientes do Instituto Brasileiro de Geografia e Estatística (IBGE). A amostra utilizada contempla dados históricos mensais de fevereiro/2002 a maio/2019. Foram utilizados o indicador geral da indústria e 23 indicadores desagregados setoriais ao desconsiderar três setores como será explicado adiante.

Não são utilizados na amostra os setores de “Manutenção, reparação e instalação de máquinas e equipamentos” e de “Impressão e reprodução de gravações” por terem sido criados apenas criados em janeiro de 2012. Esses dois setores representam uma pequena fatia na composição do índice geral (2,3%). O setor de “Fabricação de produtos do fumo” não será contemplado também na amostra, de modo a evitar multicolinearidade no uso do índice da indústria geral e dos setores que fazem parte da indústria geral na modelagem do VAR.

3.2 SHRINKAGE PRIOR NO VAR BAYESIANO

Serão estimadas as equações do VAR com as 24 variáveis: indústria geral e os demais. O modelo VAR a ser estimado com p defasagens é:

$$Y_t = c + A_1 Y_{t-1} + \dots + A_p Y_{t-p} + u_t \quad (1)$$

No qual Y_t é o vetor de variáveis no VAR (com 24 linhas), c um vetor de constantes, A o vetor de coeficientes e u_t o vetor de erros. A equação também pode ser descrita em sua forma matricial:

$$Y = XA + \epsilon \quad (2)$$

No qual $Y = (y_1, \dots, y_t)'$, $X = (X_1, \dots, X_t)'$ com $y_t = (y_{1,t}, \dots, y_{n,t})'$, $X_t = (1, y'_{t-1}, \dots, y'_{t-p})'$, $A = (c, A_1, \dots, A_p)'$, $\epsilon = (\epsilon_1, \dots, \epsilon_t)'$.

Para evitar o problema da dimensionalidade em um VAR com 24 equações, assume-se a priori que alguns coeficientes irão tender no limite a zero, tendo pesos reduzidos. Assume-se uma probabilidade a priori e estima-se a posteriori. A priori será considerada com maior peso a defasagem da variável que está sendo explicada na equação. Será considerada a primeira defasagem pelo fato de a chance de observação passada guardar correlação com a observação presente é maior em relação a outras defasagens e variáveis. Com a estimação, tem-se a posteriori. Para isso, Banbura *et al* (2010) assumem duas premissas a priori para a média dos coeficientes e a variância dos mesmos:

$$E[(A_k)_{i,j}] = \begin{cases} \delta_{i,j}, j = i, k = 1 \\ 0, \text{ caso contrário} \end{cases}, \quad V[(A_k)_{i,j}] = \begin{cases} \frac{\lambda^2}{k^2}, j = i \\ \frac{\lambda^2 \sigma_i^2}{k^2 \sigma_j^2}, \text{ caso contrário} \end{cases} \quad (3)$$

Assume-se a priori que os coeficientes A_1, \dots, A_p são independentes e normalmente distribuídos. Além disso, pressupõe-se que a matriz de covariância dos resíduos é diagonal, fixa e conhecida de modo que $E(\epsilon'\epsilon) = \Psi$, no qual $\Psi = \text{diag}(\sigma_1^2, \dots, \sigma_n^2)$.

Caso a defasagem, k , seja igual a um e o regressor seja a mesma variável dependente defasada, assume-se $\delta = 0,5$, caso contrário é estabelecido um valor zero para a *prior* dos coeficientes. O hiper-parâmetro, λ , controla a importância relativa entre a *prior* e os dados são ignorados. Se $\lambda = \infty$, o modelo ignora a prior e obtém as estimativas de mínimos quadrados ordinários (BANBURA *et al*, 2010). Utilizou-se o *default* para λ do pacote HDeconometrics do software R de modo que

$\lambda = 0,05$, seguindo Garcia *et al* (2017). Pelo lado da variância, assume-se que quando os regressores são variáveis dependentes defasadas, a variância será inversamente proporcional ao número k de defasagens. Quanto maior o número de defasagens, menor a variância. A *prior* da variância se o regressor não for uma variável dependente defasada depende de $\frac{\sigma_i^2}{\sigma_j^2}$ que considera a escala e a variabilidade diferente dos dados. Portanto, o objetivo aqui do uso da *shrinkage prior* é resolver o problema da alta dimensionalidade estabelecendo a priori no sentido de tender a zero.

3.3 ERRO QUADRÁTICO MÉDIO E TESTE DE DIEBOLD E MARIANO (1995)

Para analisar se o modelo BVAR prevê melhor em comparação a estimação *naïve* do modelo AR (1), calcula-se o erro quadrático médio dos modelos. O erro quadrático médio é dado pela média dos erros elevados ao quadrado. Os erros são a diferença entre o valor observado e o valor previsto.

$$\frac{1}{janelas} \sum_{t=1}^{janelas=92} e_t^2, \text{ em que } e_t = y_t - \hat{y}_t \quad (4)$$

Ainda, utiliza-se o teste de Diebold e Mariano (1995) para analisar se o modelo sistematicamente prevê melhor.

O teste de Diebold e Mariano (1995) é utilizado para comparação de acurácia da previsibilidade de dois modelos distintos. A hipótese nula será de que ambas as previsões possuem boa acurácia. Já a hipótese alternativa bicaudal será de que as duas previsões possuem diferentes acurácias. No caso, utilizou-se como hipótese alternativa a opção monocaudal de que as previsões do modelo de referência têm previsões melhores (menores erros de previsão) do que o modelo comparado.

São definidas uma função de perda em erro de previsão de ambos os modelos:

$$\hat{\varepsilon}_{t+h|t}^1 = y_{t+h} - \hat{y}_{t+h|t}^1 \quad (5)$$

$$\hat{\varepsilon}_{t+h|t}^2 = y_{t+h} - \hat{y}_{t+h|t}^2 \quad (6)$$

É preciso definir como *benchmark* uma das previsões para a realização do teste, os quais serão baseados nos erros quadráticos médios. O teste de Diebold e Mariano (1995) é dado da seguinte forma:

$$S = \frac{\hat{d}}{\sqrt{\widehat{Avar}(\hat{d})}} \quad (7)$$

Onde $\hat{d} = \frac{1}{T_0} \sum_{t=t_0}^T d_t$, $d_t = g(\hat{\varepsilon}_{t+h|t}^1) - g(\hat{\varepsilon}_{t+h|t}^2)$ e $\widehat{Avar}(\hat{d})$ é a variância de estimativa assintótica (para grandes amostras) de \hat{d} para a amostra selecionada. Deste modo, a estatística segue uma distribuição t-student, segundo Diebold e Mariano (1995).

4 RESULTADOS

Para previsão da série em questão por meio do modelo BVAR foi utilizado o pacote HDeconometrics no software R. De modo a tornar estacionárias as séries, utilizou-se a primeira diferença do logaritmo.

De modo a se considerar diferentes períodos de tempo, utilizou-se janelas rolantes. Ou seja, cada janela tem 100 observações na amostra para estimar o modelo. É feita a previsão e compara-se com os valores observados fora da amostra. Considerou-se 92 janelas com 100 observações. A primeira janela compreende entre a sétima observação (julho/2002) e a centésima sexta (outubro/2010), realizando a previsão 12 períodos a frente. Portanto, foram geradas 92 previsões de 1 até 12 períodos a frente.

Considerou-se o VAR bayesiano com 6 defasagens utilizando *shrinkage prior*. Para comparação como modelo *naive* foi utilizado o modelo AR (1) para as mesmas janelas rolantes do VAR bayesiano. Ou seja, espera-se um resultado melhor do VAR bayesiano do que o modelo AR (1), considerando este um modelo básico e simples.

O procedimento de comparação da performance de previsão é comparar o erro quadrático médio estimado e realizar o teste de Diebold e Mariano (1995) para analisar se sistematicamente um modelo prevê melhor em comparação ao modelo *benchmark*. Entretanto, as estatísticas são apenas para o índice da indústria geral, o qual é o objetivo do trabalho.


Na tabela 1, apresenta-se o erro quadrático médio da previsão dos modelos VAR bayesiano com *shrinkage prior* – denominado BVAR - e o modelo AR (1). Para todos os horizontes, na média o erro de previsão é menor para o modelo *naive* em comparação com o VAR bayesiano com *shrinkage prior*.

Tabela 1: Erro Quadrático Médio * 1000

	BVAR	AR (1)
1	0,67	0,53
2	0,80	0,60
3	0,95	0,76
4	1,13	0,93
5	1,34	1,15
6	1,54	1,36
7	1,87	1,68
8	2,20	2,04
9	2,56	2,41
10	2,92	2,80
11	3,37	3,25
12	3,72	3,67

O gráfico 1 apresenta os erros médios absolutos de previsão para 12 períodos a frente dos dois modelos para as diferentes janelas utilizadas. No apêndice, apresenta-se os erros de previsão dos dois modelos para 1, 3, 6 e 9 períodos a frente para as diferentes janelas utilizadas respectivamente nos gráficos 2, 3, 4 e 5. Pelo gráfico 1, o comportamento dos erros das previsões ao longo do tempo para 12 períodos a frente é semelhante. Nos períodos de previsão até meados de 2012 e de 2014 até meados de 2016, o erro de previsão dos modelos tende a ser negativo, o que significa que a previsão foi maior que o valor previsto. Em particular para o período entre 2014 até 2016 a previsão ser maior que o previsto pode-se entender por conta de ser um período de crise, fato que traz um maior período de tempo para ajustar o modelo diante das mudanças na série.

Gráfico 1: Erro de previsão BVAR X AR (1) considerando o 12º horizonte de previsão



Em seguida, foi feito o teste de Diebold e Mariano (1995) para testar como hipótese nula de que os dois modelos possuem erros de previsão idênticos estatisticamente. Assumiu-se que o modelo *naive* é o *benchmark* por apresentar o menor erro quadrático médio. A hipótese alternativa é que o erro de previsão do modelo AR (1) é menor que o erro de previsão do BVAR. A tabela 2 apresenta estatística t e o p-valor do teste de Diebold e Mariano (1995) de 1 a 12 períodos a frente. Considerando o nível de significância de 10%, pode-se dizer que o modelo *naive* apresenta melhor previsão de 1 a 3 períodos a frente. A partir de 4 períodos a frente, ambos os modelos apresentam a mesma acurácia para a previsão da variação da produção industrial agregada.

Tabela 2: Teste Diebold e Mariano (1995)

	Estatística t	P - valor
1	-3,05	0,001
2	-1,85	0,03
3	-1,48	0,07
4	-1,28	0,10
5	-1,17	0,12
6	-1,09	0,14
7	-1,03	0,15
8	-1,00	0,16
9	-0,97	0,17
10	-0,95	0,17
11	-0,94	0,17
12	-0,93	0,18

Garcia *et al* (2017) ao realizar a previsão para a inflação brasileira com modelos de alta dimensionalidade, obtém um BVAR com *shrinkage prior* com erros médios absolutos e raiz do Erro Quadrático Médio menores em relação a um modelo AR para os 12 horizontes de previsão. Em Banbura *et al* (2010) realiza-se a comparação dos erros de previsão (por meio da raiz do Erro Quadrático Médio) de modelos BVAR com *shrinkage prior* estimados com diferentes números de variáveis, considerando 3, 20 e 131 variáveis. Os autores obtiveram boa performance na previsão com adição de mais variáveis ao modelo. Apesar do modelo BVAR apresentar boa performance nos casos de Banbura *et al* (2010) e Garcia *et al* (2017), o presente trabalho chega à conclusão de que o BVAR com *shrinkage prior* com informações da produção dos setores industriais não auxilia na previsão da variação do índice de produção industrial brasileiro, de modo a não performar melhor do que o *naïve* AR (1). A não performance é justificada pelo erro quadrático médio da previsão para a produção da indústria geral ser maior em relação ao AR (1) em todos os horizontes de previsão ou pelo teste de Diebold e Mariano (1995) de 1 a 3 horizontes de tempo. Há duas possibilidades para justificativa de não obtenção do resultado esperado. A primeira é a de que as informações de produção dos setores não adicionam informação relevante para a produção da indústria geral brasileira. A segunda é a de que o modelo BVAR com *shrinkage prior* não é uma alternativa adequada para a previsão da indústria geral brasileira.

5 CONCLUSÃO

A previsão de agregados econômicas é de suma importância para que os agentes econômicos possam ter subsídios para realizar tomadas de decisões da melhor forma, sejam elas em investimentos ou consumo. Portanto, ter uma previsão bem acurada, utilizando e comparando diferentes modelos econométricos é de grande importância.

Este trabalho teve como objetivo realizar a previsão de 1 a 12 meses à frente da variação da produção da indústria geral brasileira com um modelo BVAR com *shrinkage prior* com dados dos setores da indústria, além da própria indústria geral. Utilizou-se uma base histórica proveniente do período Janeiro/2002 a Maio/2019. A comparação do resultado do modelo foi feita com o modelo *naive* AR (1). Como métricas de avaliação de acurácia foram utilizados o Erro Quadrático Médio e o Teste de Diebold Mariano (1995). Quanto a primeira métrica, encontrou-se erros menores para todos os horizontes de tempo de 1 a 12 meses para o modelo *naive*. Quanto à segunda, a um nível de significância de 10%, encontrou-se uma melhor capacidade preditiva (menores erros de previsão) para o modelo *naive* de 1 a 3 períodos a frente. A partir de 4 períodos a frente, ambos os modelos apresentam a mesma previsibilidade para a produção industrial agregada.

Pode haver duas explicações para os resultados melhores do modelo *naive*. A primeira é de que a adição de informações desagregadas não é relevante para a produção industrial brasileira. A segunda é a de que o modelo BVAR com *shrinkage prior* não é uma boa alternativa para a previsão da indústria geral brasileira. Uma limitação do trabalho foi não comparar a performance da previsão do modelo considerando um intervalo de valores para o parâmetro λ para escolher aquele mais adequado, seguindo Barboza e Vasconcelos (2019).

6 REFERÊNCIAS BIBLIOGRÁFICAS

Banbura, M., Giannone, D., e Reichlin, L. Large Bayesian Vector Auto Regressions, *Journal of Applied Economics*, Vol.25, p.71-92, 2010.

Barboza, R.d.M. e Vasconcelos, G.F.R. Measuring the aggregate effects of Brazilian Development Bank on Investment, *North American Journal of Economics & Finance*, 2018.

Barhoumi,K., Darné, O. e Ferrara, L. Are disaggregate data useful for factor analysis in forecasting French GDP, *Journal of Forecasting*, 2010

Carlos, T.C. e Marçal, E.F. Forecasting Brazilian inflation by its aggregate and disaggregated data: a test of predictive power by forecast horizon, *São Paulo School of Economics: Working Papers Series*, n.1, 2013.

Clark, T.E, West, K.D. Aproximate Normal Test For Equal Predictive Accuracy In Nested Models. *National Bureau Of Economics Research*, 2006 (Technical Working Paper 326).

Diebold, F.X; Mariano, R.S. Comparing predictive accuracy. *Journal of Bussiness & Economic Statistics*, Taylor & Francis, v. 20, n.1, p.133-144, 1995.

Duarte, C. e Rua, A. Forecasting inflation through a bottom-up approach: the portuguese case. *Economic Modelling*, 24, 941-953, 2005.

Espasa, A., Senra, E. e Albacete, R. Forecasting inflation in the European monetary union: A disaggregated approach by countries and by sectors, *The European Journal of Finance*, Vol.8, n.4, p.402-421, 2002.

Hansen, P.R., Lunde, A., Nason,J.M. The model confidence set. 2010.

Garcia, M.G.P., Medeiros, M.C., Vasconcelos, G.F.R. Real-time inflation forecasting with high-dimensional models: The case of brazil, *International Journal of Forecasting*, 2017.

Gorshay, Centurial evidence of breaks in the persistence of unemployment, *Economics Letters*, 2015.

Hendry, D.F e Hubrich, K. Combining disaggregate forecasts or combining disaggregate information to forecast an aggregate, *European Central Bank: Working Papers*, n.115, 2010.

Lütkepohl, H. *Forecasting Contemporaneously Aggregated Vector ARMA Processes*, 1984.

Marcellino, M., Stock, J.H. e Watson, M.W., A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series, *Journal of Econometrics*, 2006.

Prince, D. Marçal, E.M, Pereira, P.L.V, Forecasting Industrial Production Index by its aggregated or disaggregated data? Evidence from one important emerging economy, *Working Paper*, 2019.

Stock, J.H. e Watson, M.W. Forecasting Inflation, *Journal of Monetary Economics*, 1998.

Tobias, J. e Zellner, A. Further Results on Bayesian Method of Moments Analysis of the Multiple Regression Model, 1998.

Vasconcelos, G. Realy, Realy Big VARs. insightR, 2017. Disponível em: < <https://insightr.wordpress.com/2017/04/27/realy-realy-big-vars/#more-138> >. Acesso em 16/11/2019.

Weber, E. e Zika, G. Labour Market forecasting: Is disaggregation useful?, *Institute for Employment Research: Discussion Paper*, n.14, 2013.

7 APÊNDICE

Previsões considerando primeiro, terceiro, sexto e nono horizontes de previsão:

Gráfico 2: Erro de previsão BVAR X AR (1) considerando o 1º horizonte de previsão




Gráfico 3: Erro de previsão BVAR X AR (1) considerando o 3º horizonte de previsão




Gráfico 4: Erro de previsão BVAR X AR (1) considerando o 6º horizonte de previsão




Gráfico 5: Erro de previsão BVAR X AR (1) considerando o 9º horizonte de previsão

